

## PEMODELAN GENERAL REGRESSION NEURAL NETWORK (GRNN) PADA DATA RETURN INDEKS HARGA SAHAM EURO 50

Rezzy Eko Caraka<sup>1</sup>, Hasbi Yasin<sup>2</sup>, Alan Prahutama<sup>3</sup>

<sup>1</sup>Mahasiswa Jurusan Statistika FSM UNDIP

<sup>2,3</sup>Staf Pengajar Jurusan Statistika FSM UNDIP

### ABSTRAK

*General Regression Neural Network* (GRNN) merupakan salah satu model jaringan radial basis yang digunakan untuk pendekatan suatu fungsi. Model GRNN termasuk model jaringan syaraf tiruan dengan solusi yang cepat, karena tidak diperlukan iterasi yang besar pada estimasi bobot-bobotnya. Model ini memiliki arsitektur jaringan yang baku, dimana jumlah unit pada *pattern layer* sesuai dengan jumlah data input. Salah satu aplikasi GRNN adalah untuk memprediksi nilai *return* saham dari indeks Euro 50 CFD (*Contract For Difference*). Indeks Euro 50 CFD (*Contract For Difference*) digunakan sebagai patokan harga saham dari 50 perusahaan terbesar di zona Eropa. Para investor melakukan investasi di saham indeks Euro 50 CFD (*Contract For Difference*) dengan harapan mendapatkan kembali keuntungan yang sesuai dengan apa yang telah di investasikannya. Dengan menggunakan model GRNN diperoleh bahwa nilai RMSE dan  $R^2$  untuk data *training* sebesar 0,00095 dan 99,19%. Untuk data *testing* diperoleh nilai RMSE dan  $R^2$  sebesar 0,00725 dan 98,46%. Berdasarkan nilai prediksi *return* saham dua belas hari ke depan diperoleh kerugian tertinggi atau *capital loss* pada 15 Desember 2014 sebesar 5,583188% dan profit tertinggi atau *capital gain* pada tanggal 10 Desember 2014 sebesar 2,267641%

**Kata Kunci:** GRNN, Jaringan Syaraf Tiruan, Return Saham, Indeks Euro 50, Kerugian Tertinggi, Profit Tertinggi, Prediksi

### 1. PENDAHULUAN

Meningkatnya kebutuhan perencanaan dalam aktivitas bisnis dan ekonomi, mengakibatkan prediksi terhadap kondisi mendatang secara akurat semakin diperlukan. Dalam bidang ekonomi harga saham merupakan acuan penting yang perlu diperhatikan oleh para investor sebelum melakukan investasi. Harga saham mengalami fluktuasi baik berupa kenaikan maupun penurunan sehingga dengan harga saham yang berfluktuasi memberikan peluang kepada para investor untuk mengalami keuntungan maupun kerugian.

Indeks *Euro* digunakan sebagai patokan harga saham dari 50 perusahaan terbesar di zona Eropa. Indeks ini mencakup bank-bank Eropa terkemuka, perusahaan petroleum, perusahaan telekomunikasi dan elektronik, industri mobil dan lainnya

*Return* atau pengembalian adalah keuntungan yang diperoleh perusahaan, individu dan investasi dari hasil kebijakan investasi yang dilakukan. Penggunaan data *return* saham dalam bidang ekonomi memberikan keuntungan yaitu peningkatan dan penurunan harga saham tersebut akan terlihat jelas jika diamati. Jika model deret waktu (ARIMA) digunakan untuk memodelkan *return* saham, maka akan menghasilkan ragam sisaan yang tidak konstan, sebagai akibat dari karakteristik *return* saham itu sendiri dengan jumlah frekuensi tinggi (Tsay, 2002). Semakin tinggi harga saham akan menghasilkan *capital gain* yang besar pula. *Capital gain* merupakan selisih antara pembelian saham dengan nilai penjualan saham.

Peramalan adalah suatu kegiatan memperkirakan apa yang terjadi pada masa yang akan datang berdasarkan nilai sekarang dan masa lalu dari suatu peubah (Makridakis, 1999). Peramalan merupakan suatu unsur yang sangat penting terutama dalam perencanaan dan pengambilan keputusan. Adanya tenggang waktu antara suatu peristiwa dengan peristiwa yang terjadi mendatang merupakan alasan utama bagi peramalan dan perencanaan. Dalam situasi tersebut peramalan merupakan alat yang penting dalam perencanaan yang efektif serta efisien.

Pemilihan metode dalam peramalan tergantung pada beberapa aspek penelitian yaitu aspek waktu, pola data, tipe model sistem yang diamati, dan tingkat keakuratan peramalan. Penggunaan metode tersebut dalam peramalan harus memenuhi asumsi-asumsi yang digunakan. Kendala yang dihadapi dalam melakukan peramalan terhadap data saham adalah data yang berubah dengan keacakannya. Hal ini disebabkan pada kasus data finansial dan keuangan memiliki fluktuasi yang sangat besar dan tidak tetap. Sehingga model ARIMA kurang bagus untuk memodelkan data saham yang fluktuatif.

Selain metode peramalan konvensional yang dipakai dalam melakukan peramalan, metode peramalan menggunakan *Neural Network* (NN) dapat dipakai sebagai alternatif dalam melakukan peramalan. Secara umum terdapat tiga jenis NN berdasarkan arsitekturnya yaitu *single layer neural network*, *multi layer neural network*, *recurrent neural network*.

Ada beberapa model NN diantaranya adalah *General Regression Neural Network* (GRNN), *Kohonen Neural Network*, *Learning Vector Quantization* (LVQ), dan *Feed Forward Neural Networks* (FFNN). Pada umumnya, *General Regression Neural Network* (GRNN), merupakan salah satu model jaringan radial basis yang sering digunakan untuk pendekatan suatu fungsi. Leung, *et.al* (2000) menerangkan bahwa dasar dari operasi GRNN secara esensial didasarkan pada teori regresi non linier (kernel) dimana estimasi dari nilai harapan output ditentukan oleh himpunan input-inputnya. Oleh karena itu peneliti tertarik untuk memodelkan dan meramalkan indeks harga saham Euro 50 dengan *General Regression Neural Network* (GRNN).

## **2. TINJAUAN PUSTAKA**

### **2.1 Indeks Harga Saham**

Indeks harga saham adalah harga saham yang dinyatakan dalam angka indeks. Indeks harga saham digunakan untuk analisis dan menghindari dampak negatif dari penggunaan harga saham. Selain itu, menurut Samsul,M (2006) tujuan lain dari indeks harga saham adalah sebagai indikator utama yang menggambarkan pergerakan harga saham secara individu atau kelompok. Indeks harga saham diharapkan memiliki fungsi sebagai indikator dari *trend* pasar dan tingkat keuntungan, parameter kinerja suatu portofolio, memfasilitasi pembentukan portofolio dengan strategi pasif, dan memfasilitasi berkembangnya produk derivatif.

Indeks *Euro 50* atau disebut juga *Euro 50 CFD* (*Contract For Difference*) digunakan sebagai patokan harga saham dari 50 perusahaan terbesar di zona Eropa. Indeks ini mencakup bank-bank Eropa terkemuka, perusahaan petroleum, perusahaan telekomunikasi dan elektronik, industri mobil dan lainnya. Indeks *Euro 50 CFD* (*Contract For Difference*) mencakup 50 saham dari 12 zona Eropa, negara yang tergabung dalam indeks ini adalah Austria, Belgia, Finlandia, Perancis, Jerman, Yunani, Irlandia, Italia, Luksemburg, Belanda, Portugal dan Spanyol. Indeks *Euro 50 CFD* (*Contract For Difference*) merupakan patokan pasar saham yang paling diakui di zona Eropa dan sebesar 60% dari total kapitalisasi pasar dari perusahaan zona Euro yang tercantum, yaitu sebagian besar saham publik dan diperdagangkan secara teratur.

### **2.2 Return dan Risiko**

Risiko adalah penyimpangan dari *return* yang diharapkan dalam sebuah kegiatan investasi. Risiko didefinisikan sebagai variabilitas *return* terhadap *return* yang diharapkan. Risiko biasanya dihitung dengan menggunakan standar deviasi dari *return* historis.

*Return* atau pengembalian adalah keuntungan yang diperoleh perusahaan atau individu dari hasil kebijakan investasi yang dilakukan. Penggunaan data *return* saham dalam bidang ekonomi memberikan keuntungan yaitu peningkatan dan penurunan harga saham tersebut akan terlihat jelas jika diamati perbandingan nilai harga saham saat ini dengan harga saham

sebelumnya. Nilai *return* akan bernilai positif jika terjadi kenaikan harga saham, dan bernilai negatif jika terjadi penurunan harga saham, sehingga fluktuasi harga saham dapat terlihat jika digunakan data *return*. Anggap  $Y_t$  sebagai respons pada waktu ke- $t$  atau harga saham pada waktu ke  $t$  dan  $Y_{t-1}$  sebagai respons pada waktu ke  $t-1$  atau harga saham pada waktu  $t-1$ , pendekatan untuk fluktuasi harga didefinisikan sebagai *log return* yaitu :

$$\begin{aligned} X_t &= \log \frac{Y_t}{Y_{t-1}} \\ X_t &= \log Y_t - \log Y_{t-1} \\ Y_t &= 10^{X_t} \cdot Y_{t-1} \end{aligned} \quad (1)$$

### 2.3 Analisis Deret Waktu

Data deret waktu merupakan sekelompok pengamatan yang diperoleh pada titik waktu yang berbeda dengan selang waktu yang sama dan barisan data diasumsikan saling berhubungan satu sama lain (Box dan Jenkins, 1994). Analisis deret waktu merupakan serangkaian pengamatan yang disusun menurut waktu dan mempertimbangkan pengaruh waktu di mana data pengamatan bersifat acak dan saling berhubungan secara statistik.

### 2.4 Fungsi Autokorelasi (ACF)

Autokorelasi menyatakan bagaimana keterkaitan nilai  $Y_t$  dengan  $Y_{t-k}$ , di mana  $k = 1, 2, \dots$  merupakan waktu data pada waktu sebelumnya atau *lag*. Menurut (Makridakis *et.al*, 1999). fungsi autokorelasi  $\rho_k$  dapat diduga dengan  $r_k$  :

$$\begin{aligned} r_k &= \frac{\sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \\ \bar{Y} &= \frac{\sum_{t=1}^n Y_t}{n} \end{aligned} \quad (2)$$

di mana :

- $r_k$  = fungsi autokorelasi
- $Y_t$  = respons pada waktu  $t$
- $Y_{t-k}$  = respons pada waktu  $t-k$
- $\bar{Y}$  = rata-rata respons
- $n$  = ukuran sampel

### 2.5 Fungsi Autokorelasi Parsial (PACF)

Autokorelasi parsial digunakan untuk mengukur tingkat keeratan antara  $Y_t$  dan  $Y_{t-k}$ , apabila pengaruh dari lag dianggap terpisah (Makridakis *et.al*, 1999). Pendugaan dari PACF merupakan koefisien autokorelasi dari persamaan *Yule-Walker* untuk  $j = 1, 2, \dots, k$  :

$$\begin{aligned} \rho_1 &= \phi_{k1}\rho_0 + \phi_{k2}\rho_1 + \dots + \phi_{kk}\rho_{k-1} \\ \rho_2 &= \phi_{k1}\rho_1 + \phi_{k2}\rho_0 + \dots + \phi_{kk}\rho_{k-2} \\ &\vdots \\ \rho_k &= \phi_{k1}\rho_{k-1} + \phi_{k2}\rho_{k-2} + \dots + \phi_{kk} \end{aligned} \quad (3)$$

Sehingga pendugaan dari PACF adalah sebagai berikut :

$$\begin{aligned} \hat{\phi}_{kk} &= \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j}\rho_{k-1}}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j}\rho_j} \\ \hat{\phi}_{kj} &= \hat{\phi}_{k-1,j} - \hat{\phi}_{kk}\hat{\phi}_{k-1,k-j} \end{aligned} \quad (4)$$

### 2.6 Neural Network

Jaringan Syaraf Tiruan (JST) atau yang biasa disebut *Artificial Neural Network* (ANN) merupakan sistem pemrosesan informasi yang memiliki karakteristik mirip dengan jaringan syaraf pada makhluk hidup. Dalam perkembangan selanjutnya huruf "A" pada istilah ANN sering dihilangkan untuk mempersingkat penulisan sehingga lebih populer dengan istilah *Neural Network* (NN) saja. NN pertama kali diperkenalkan oleh McCulloch dan Pitts

(1943) yaitu berupa suatu model sederhana dari suatu syaraf nyata dalam otak manusia atau jaringan jaringan syaraf makhluk hidup

## 2.7 General Regression Neural Network

*General Regression Neural Network* (GRNN) merupakan salah satu model jaringan radial basis yang sering digunakan untuk pendekatan suatu fungsi. Dasar dari operasi GRNN secara esensial didasarkan pada regresi nonlinear (kernel) dimana estimasi dari nilai harapan output ditentukan oleh himpunan input-inputnya (Leung *et.al*, 2000). Walaupun GRNN menghasilkan output berupa vektor multivariate, dengan tidak mengurangi keumuman deskripsi dari logika operasi GRNN pada bagian ini disederhanakan untuk kasus output univariat saja. Persamaan (5) meringkas logika GRNN dalam formula regresi nonlinear:

$$E[y|x] = \frac{\int_{-\infty}^{\infty} yf(x,y)dy}{\int_{-\infty}^{\infty} f(x,y)dy} \quad (5)$$

Dalam hal ini  $y$  adalah output yang diprediksi oleh GRNN, sedangkan  $X$  adalah vektor input  $(x_1, x_2, \dots, x_p)$  yang terdiri dari  $p$  variabel prediktor.  $E[y|x]$  adalah harga harapan dari output  $y$  diberikan vektor input  $X$  dan  $f(X,y)$  adalah fungsi densitas probabilitas bersama dari  $X$  dan  $y$ .

Teori *General Regression Neural Network* diperoleh dari estimasi densitas kernel multivariate (Sprecht,1991). Tujuan dari estimasi multivariate nonparametrik ini yaitu mengestimasi fungsi densitas probabilitas  $F(z_1^*, \dots, z_m^*)$  dari  $m$  variabel acak  $z = (z_1, \dots, z_m)^T$  dengan menggunakan  $n$  ukuran dari tiap variabel. Estimator densitas kernel multivariate pada kasus  $m$  dimensi didefinisikan sebagai

$$F(z^*) = \frac{1}{n} \sum_{i=1}^n \frac{1}{h_1 \dots h_m} k\left(\frac{z_{i1}-z_1^*}{h_1}, \dots, \frac{z_{im}-z_m^*}{h_m}\right) \quad (6)$$

Dimana  $K$  adalah fungsi kernel multivariate dan *bandwidth* (parameter penghalusan) vektor  $h = (h_1, \dots, h_m)^T$ . Data asli  $Z(X_i, Y_i); i=1, \dots, n$  akan dibagi menjadi himpunan data *training* digunakan untuk pengembangan model, sedangkan himpunan data *training* berasal dari suatu proses sampling yang mengukur nilai output dengan *additive random noise*:

$$z_i = E[Z|x, y] + \varepsilon_i \quad (7)$$

dimana  $\varepsilon_i \sim NID(0, \sigma^2)$

Mean bersyarat dari  $Z$  jika diberikan ke  $(x,y)$  yang dikenal sebagai suatu regresi  $Z$  pada  $(x,y)$  adalah suatu solusi yang meminimalkan MSE. Jika  $f(x,y,Z)$  adalah fungsi densitas probabilitas kontinu bersama maka mean bersyarat tersebut adalah :

$$E[Z|x, y] = \frac{\int_{-\infty}^{\infty} Z \cdot f(x,y,Z) dZ}{\int_{-\infty}^{\infty} f(x,y,Z) dZ} \quad (8)$$

Fungsi densitas  $f(x,y,Z)$  dapat diestimasi dari data dengan menggunakan estimator konsisten nonparametrik sebagai berikut :

$$f(x, y, Z) = \frac{1}{[(2\pi)^{\frac{p+1}{2}} \sigma^p]} \frac{1}{n} \sum_{i=1}^n \exp\left(-\frac{(X-X_i)^T}{2\sigma^2}\right) \exp\left[-\frac{(Y-Y_i)}{2\sigma^2}\right] \quad (9)$$

dengan  $p$  banyaknya lag input dan  $n$  adalah banyaknya pengukuran dalam himpunan data *Training*,  $h$  adalah suatu panjang bidang, serta jarak metrik ( $D_i^2$ ) adalah :

$$D_i^2 = (X - X_i)^T (X - X_i) \quad (10)$$

Dengan mensubstitusi estimasi probabilitas bersama (9) ke dalam mean (8) bersyarat diperoleh estimator kernel Nadaraya-Watson sebagai berikut:

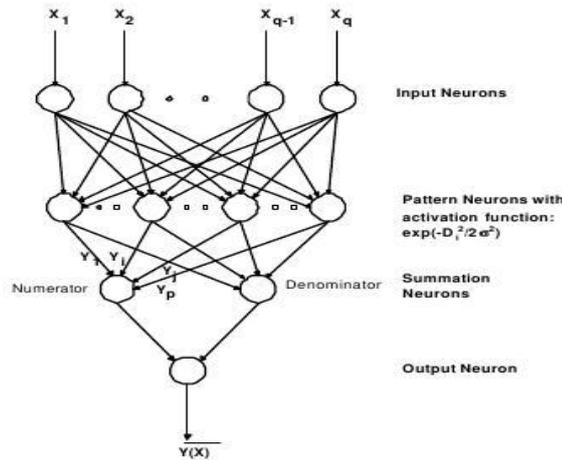
$$Z_m(X, Y) = \frac{\sum_{i=1}^n z_i \exp\left(-\frac{D_i^2}{2h^2}\right)}{\sum_{i=1}^n \exp\left(-\frac{D_i^2}{2h^2}\right)} \quad (11)$$

## 2.8 Struktur dan Arsitektur GRNN

Dalam hal ini  $y$  adalah output yang diprediksi oleh GRNN, sedangkan  $x$  adalah vektor input  $(x_1, x_2, \dots, x_p)$  yang terdiri dari  $p$  variabel prediktor.  $E[y|x]$  adalah harga harapan dari

ouput y jika diberikan vektor input X dan  $f(X,y)$  adalah fungsi densitas probabilitas bersama X dan y.

Konstruksi GRNN terdiri dari empat layer pemrosesan yaitu neuron input, pattern, summation dan output. Input layer menerima vektor input X dan mendistribusikan data ke pattern layer. Tiap-tiap neuron dalam pattern layer kemudian membangun output  $\theta$  dan mengirimkan hasilnya ke summation layer. Neuron-neuron *numerator* dan *denominator summation layer* menghitung jumlahan aritmatik sederhana dan terboboti yang didasarkan pada nilai  $\theta$  dan  $w_{ij}$  yang diperoleh berdasarkan pembelajaran melalui *training* dengan *supervise*. Neuron pada *output layer* kemudian melakukan pembagian terhadap jumlahan yang telah dihitung oleh neuron-neuron pada *summation layer*.



Gambar 1. Konstruksi GRNN Secara Umum

Tiap-tiap layer unit pemrosesan ditandai dengan suatu fungsi yang spesifik. Layer pertama disebut neuron input (*input neurons*), bertanggung jawab untuk menerima informasi. Terdapat suatu neuron input tunggal untuk setiap variabel prediktor dalam vektor input X. tidak ada pemrosesan data yang dilakukan pada neuron-neuron input tersebut. Neuron input kemudian mengirimkan data ke layer kedua dari unit pemrosesan yang disebut neuron-neuron pola (*pattern neurons*). Dalam hal ini, jumlah neuron pola sama dengan jumlah kasus dalam himpunan *training*. Neuron pola ke  $i$  mendapatkan data dari neuron input dan menghitung output  $\theta_i$  menggunakan fungsi transfer:

$$\theta_i = e^{-(X-U_i)'(X-U_i)/2\sigma^2} \tag{11}$$

Dalam hal ini X adalah vektor input dari variabel prediktor untuk GRNN,  $U_i$  adalah vektor *training* khusus yang direpresentasikan oleh neuron pola,  $i$  dan  $\sigma$  adalah parameter *smoothing*.

Output dari neuron pola kemudian diteruskan ke layer ketiga dari unit pemrosesan yang disebut neuron jumlahan (*summation neurons*) dimana output dari semua neuron pola ditambahkan. Secara teknis ada dua tipe penjumlahan terboboti. Dalam topologi GRNN terdapat unit pemrosesan terpisah yang melakukan penjumlahan aritmatik sederhana dan penjumlahan terboboti. Persamaan (11.a) dan (11.b) masing-masing menyatakan operasi matematis yang dibentuk oleh penjumlahan terboboti

$$S_s = \sum_i \theta_i \tag{11.a}$$

$$S_w = \sum_i w_i \theta_i \tag{11.b}$$

$S_s$  adalah *simple arithmetic summation* dan  $S_w$  adalah *summation* terboboti. Jumlahan yang dihasilkan oleh *summation neurons* secara berturut-turut dikirimkan ke layer dari unit pemrosesan yaitu neuron output. Neuron output membentuk pembagian berikut untuk mendapatkan output regresi GRNN y:

$$y = \frac{S_w}{S_s} \tag{11.c}$$

## 2.9 Normalisasi Data dan Denormalisasi Data

Dalam tahapan pemrosesan awal (*pre processing*) data, normalisasi input ke dalam skala yang sama merupakan tahapan yang biasanya dalam *neural network*. Hal ini sangat berguna terutama ketika setiap variabel mempunyai karakteristik yang berbeda.

Tahap kedua adalah denormalisasi data. Denormalisasi data penting dilakukan agar data hasil peramalan dengan GRNN dapat dilihat secara mudah dalam nilai yang sama dengan asalnya.

## 2.10 Training GRNN dengan Data Return

GRNN merupakan salah satu *training* Jaringan Syaraf Tiruan dengan *supervised* (dalam pengawasan). Jaringan melakukan *training* dan pembelajaran dengan menguji hubungan antara tiap pasangan vektor data peubah input X, output y yang berhubungan juga diamati serta akhirnya menarik kesimpulan dengan didasari fungsi khusus serta meringkas semua hubungan yang ditemui pada himpunan data *training*.

Jaringan melakukan *training* dengan menguji hubungan antara tiap pasangan vektor input X. Setelah itu, jaringan melakukan pembelajaran dengan membuat sebuah neuron pola untuk tiap kasus *training*. Langkah ini diulang hingga semua kasus di dalam himpunan *training* divalidasi.

Periode yang paling menentukan dimulai setelah *training* jaringan, jaringan dilatih lalu dihitung estimasi nilai dari hasil *training* jaringan. Estimasi nilai hasil *Training* jaringan dibandingkan dengan sampel nyata yang diamati dan parameter jaringan yang telah disesuaikan sehingga diperoleh error hasil *training*. Error hasil pelatihan digunakan untuk mencari MSE (*Mean Square Error*) dan RMSE (*Root Mean Square Error*) hasil *training*. Nilai  $R^2$  menunjukkan proporsi jumlah kuadrat total yang dapat dijelaskan oleh sumber keragaman peubah bebas.

$$MSE = \frac{1}{Q} \sum_{k=1}^Q (t_k - y_k)^2 \quad (12)$$

$$RMSE = \sqrt{\frac{1}{Q} \sum_{k=1}^Q (t_k - y_k)^2} \quad (13)$$

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST} \quad (14)$$

## 2.11 Capital Gain

*Capital gain* merupakan selisih antara nilai pembelian saham dengan nilai penjualan saham. Pendapatan yang berasal dari *capital gain* disebabkan harga jual saham lebih besar dari pada harga beli. Secara matematis *capital gain* didefinisikan sebagai berikut :

$$C = \frac{Y_j - Y_b}{Y_b} \quad (15)$$

dengan :

C : *Capital gain*

$Y_j$  : Harga penjualan saham

$Y_b$  : Harga pembelian saham

Berdasarkan persamaan 15 maka dapat dihitung besarnya keuntungan yang diperoleh dari investasi dapat dirumuskan sebagai berikut :

$$P = M \cdot C \quad (16)$$

dengan :

P : profit atau keuntungan

M : besarnya investasi

C : *capital gain*

## 3. METODOLOGI PENELITIAN

Data yang digunakan adalah data sekunder, yaitu data penutupan indeks harga saham harian *Euro 50 CFD* dari tanggal 02 januari 2013 sampai dengan 27 november 2014 yang

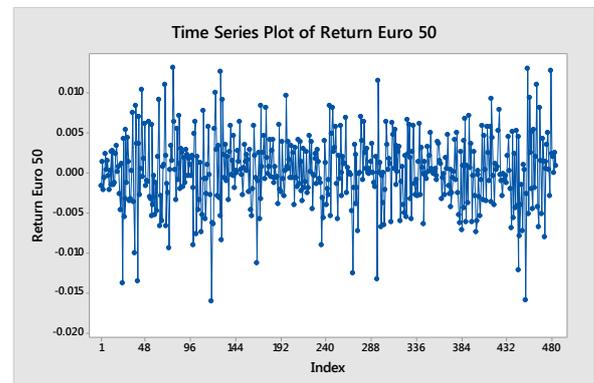
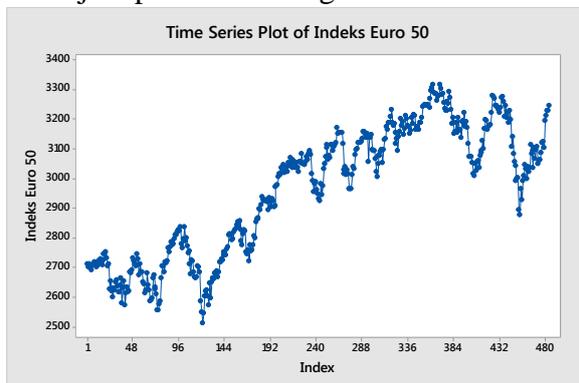
terdiri dari 484 data dan dilakukan *return* sehingga terdapat 483 data yang akan digunakan. Data tersebut diperoleh dari website google finance ([www.google.com/finance](http://www.google.com/finance)). langkah-langkah memodelkan meliputi hal-hal sebagai berikut :

1. Diketahui sejumlah data *return* ( $Y_t$ ) runtun waktu  $t_1, t_2, \dots, t_n$  selanjutnya dipakai untuk memperkirakan nilai  $t_{n+1}$  berdasarkan  $t_1, t_2, \dots, t_n$ .
2. Menentukan input dan target dari model GRNN sesuai lag yang didapatkan pada plot PACF.
3. Menentukan jumlah *hidden layer* dan *node* pada masing-masing *layer*.
4. Membagi data berdasarkan data *training* dan data *testing*. Pada penelitian ini menggunakan 80% data *training* dan 20% data *testing*
5. Dilakukan preprocessing menggunakan bentuk normal
6. Membangun jaringan GRNN
7. Peramalan

#### 4. HASIL DAN PEMBAHASAN

##### 4.1 Aplikasi *General Regression Neural Network* pada *Data Time Series*

Pada pemodelan *General Regression Neural Network* (GRNN) untuk data *time series*, langkah awal pemodelan GRNN adalah plot dari data penutupan saham (*close*). Plot dari data bertujuan untuk mengetahui karakteristik dari indeks harga saham. Plot data dapat dilihat pada Gambar 2.a . Langkah selanjutnya adalah plot *return*. Penggunaan *return* memberikan banyak informasi terutama dalam mengetahui fluktuasi saham. Pada Gambar 2.b menunjukkan nilai *return* akan positif jika terjadi kenaikan harga saham, dan bernilai negatif jika terjadi penurunan harga saham.



Gambar 2. Time Series Plot

(a) Harga Penutupan Saham Indeks Euro 50 CFD

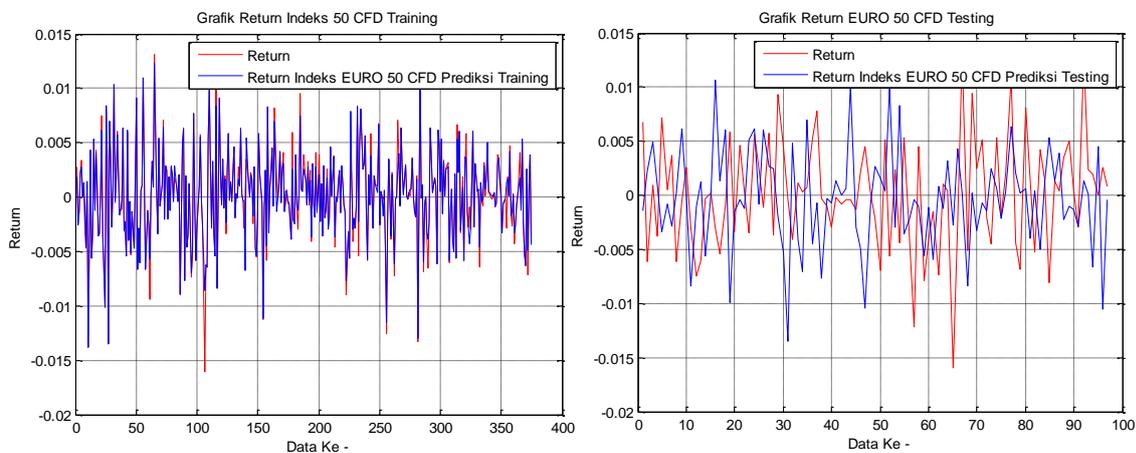
(b). Return Indeks Euro 50 CFD

##### 4.2 Penentuan Input dan Target Jaringan

Pada pemodelan *time series*, data masa kini dipengaruhi oleh data masa lalu sehingga dalam hal ini input data pada model GRNN adalah data masa lalu (lag time) dan targetnya adalah data masa kini, sebagaimana terminologi autoregressif pada metode ARIMA Box-Jenkins (Warsito, 2009). Identifikasi lag sebagai komponen input didasarkan pada lag-lag yang memiliki nilai PACF terbesar. Hal ini dikarenakan karakteristik persamaan model GRNN memiliki kesamaan dengan model AR. Berdasarkan identifikasi lag diperoleh 3 variabel lag yang akan dijadikan sebagai komponen return data input, yaitu lag 1, 2, dan 12 atau dapat dikatakan bahwa  $X_t$  dipengaruhi oleh  $X_{t-1}, X_{t-2}, X_{t-12}$ . Penerapan *General Regression Neural Network* dalam peramalan terdiri dari dua tahap yaitu tahap pelatihan dan tahap pengujian. Pada tahap pelatihan digunakan untuk pengembangan model GRNN, sedangkan pada tahap pengujian digunakan untuk estimasi model GRNN yang berkualitas.

### 4.3 Pemodelan GRNN pada Data Return

Untuk melihat indikasi apakah seorang investor mengalami keuntungan maupun kerugian dalam berinvestasi dapat dilihat dengan *return*. Suatu jaringan GRNN terdiri dari empat lapisan unit pemroses yaitu lapisan input, lapisan pola, lapisan jumlahan (*summation layer*) dan lapisan output. Pada lapisan input terdiri dari 3 unit neuron yang mewakili data return serta 1 unit bias input (b). 1 unit bias input lalu meneruskan data ke lapisan pola dengan nama bobot input yang nilainya sama dengan data dari neuron input, langkah ini diulang terus menerus sampai semua data pada neuron input terkirim lengkap ke neuron-neuron pola. 1 unit neuron bias juga meneruskan data ke lapisan pola dengan nama bobot bias input yang nilainya sama dengan  $1/spread$ , langkah ini diulang terus sampai semua data pada neuron bias terkirim lengkap ke neuron pola. Untuk melihat perbandingan antara target dengan output jaringan untuk data Pelatihan dan data pengujian dapat dilihat di Gambar 3.a dan Gambar 3.b Dari gambar tersebut dapat dilihat bahwa perbandingan antara target dan data pengujian saling berdekatan, yang berarti bahwa pemodelan GRNN untuk data return indeks harga saham euro 50 dapat dikatakan cukup berhasil.



Gambar 3. Plot Data

(a).Return Indeks Euro 50 In-Sample (b). Return Indeks Euro 50 Out Of Sample

### 4.4 Pembentukan Arsitektur Jaringan dan Peramalan

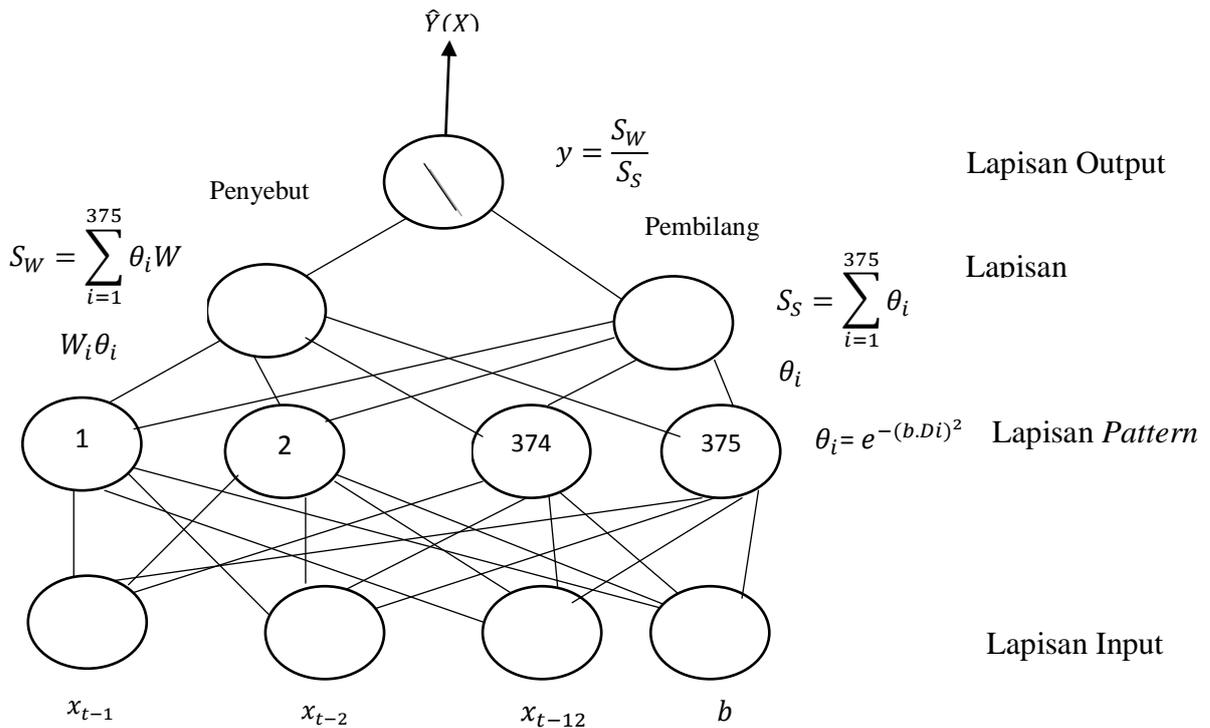
Arsitektur jaringan yang akan digunakan dalam model GRNN adalah jaringan multilapis (*multilayer*) yang terdiri dari lapisan input (*input layer*), *Pattern Neuron*, *summation neuron* dan lapisan output (*output layer*). Berdasarkan Arsitektur GRNN yang telah dibentuk dengan jumlah neuron pola sama dengan jumlah kasus dalam himpunan training.

Pada Gambar 4 diperoleh model GRNN (pada *output layer*) untuk peramalan data *return* indeks harga saham Euro adalah  $X_t = \frac{S_W}{S_S}$ , sedangkan pada *summation layer*  $S_W = \sum_{i=1}^{375} \theta_i W_i$  dan  $S_S = \sum_{i=1}^{375} \theta_i$ . Setelah itu dapat menghitung nilai *error training* sebanyak 375 data dengan cara mengurangkan data aktual indeks *return* dengan data *indeks return* yang dilakukan simulasi. Selain itu untuk menghitung *error testing* dengan cara mengurangkan data 96 data indeks aktual *return* dengan data simulasi

$$MSE\ Training = \frac{1}{375} \sum_{i=1}^{375} ((0,002723 - 0,00189)^2 + (-0,00158 - (-0,00256))^2 + (-0,00135 - (-0,00154))^2 + \dots + (-0,0044 - -0,00427)^2) = 0,00000092$$

$$RMSE\ Training = \sqrt{0,00000092} = 0,000958508$$

$$R^2\ Training = 1 - \frac{SSE}{SST} = 0,9919$$



Gambar 4. Arsitektur Jaringan

$$MSE \text{ Testing} = \frac{1}{96} \sum_1^{96} (((0,006722) - (-0,00147))^2 + ((-0,00616) - 0,002284)^2 + \dots + (-0,0004 - 0,001202)^2) = 0,000052684$$

$$RMSE \text{ Testing} = \sqrt{0,000052684} = 0,007258401$$

$$R^2 \text{ Testing} = 1 - \frac{sse}{sst} = 0,9846$$

Dari bobot yang telah optimum hasil pelatihan maka model GRNN untuk data *return* indeks harga saham Euro 50 CFD (*Contract For Diffrence*) dapat dituliskan sebagai berikut :

$$\hat{X}_t = \frac{S_W}{S_S} = \frac{\sum_{i=1}^{375} W_i \times \theta_i}{\sum_{i=1}^{375} \theta_i} = \frac{\sum_{i=1}^{375} W_i \times e^{-(b\sqrt{(X_{t-1}-X_{t-i})^2+(X_{t-2}-X_{t-2i})^2+(X_{t-12}-X_{t-12i})^2})}}{\sum_{i=1}^{375} e^{-(b\sqrt{(X_{t-1}-X_{t-i})^2+(X_{t-2}-X_{t-2i})^2+(X_{t-12}-X_{t-12i})^2})}}$$

Dimana  $W_i$  = bobot lapisan hasil Pelatihan jaringan GRNN

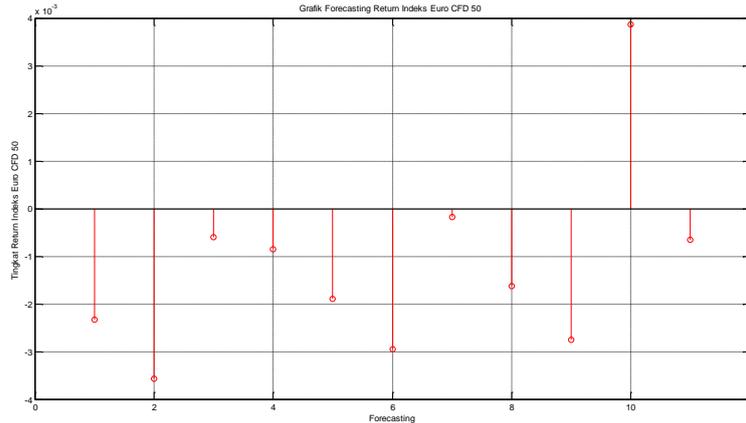
$\theta_i$  = nilai-nilai masing neuron pada layer pola

Dilakukan prediksi satu langkah kedepan yaitu prediksi *return* indeks harga saham Euro 50 CFD (*Contract For Diffrence*) menggunakan bobot-bobot yang telah optimal:

$$\begin{aligned} \hat{X}_t &= \frac{S_W}{S_S} = \frac{\sum_{i=1}^{375} W_i \times \theta_i}{\sum_{i=1}^{375} \theta_i} = \frac{\sum_{i=1}^{375} W_i \times e^{-(b\sqrt{(X_{t-1}-X_{t-i})^2+(X_{t-2}-X_{t-2i})^2+(X_{t-12}-X_{t-12i})^2})}}{\sum_{i=1}^{375} e^{-(b\sqrt{(X_{t-1}-X_{t-i})^2+(X_{t-2}-X_{t-2i})^2+(X_{t-12}-X_{t-12i})^2})}} \\ &= \frac{(0,83255 \times 0,26410) + (0,83255 \times (-0,13445)) + \dots + (0,83255 \times (-0,42708))}{(0,26410 + (-0,13445) + \dots + (-0,42708))} \\ &= -0,00233 \end{aligned}$$

Sehingga hasil prediksi satu langkah kedepan untuk nilai *return* 28 November 2014 indeks harga saham Euro 50 CFD (*Contract For Diffrence*) menggunakan bobot yang telah optimal adalah -0,00233. Untuk membuat peramalan periode ke depan disusun fungsi `function[b]=forecastgrnn_Return(das)`.

Pada fungsi ini juga telah dibuat plot hasil peramalan ke depan dalam bentuk stem dapat dilihat pada Gambar 5.



Gambar 5. Peramalan Return Indeks Euro 50

Hasil ramalan menunjukkan bahwa untuk periode 12 hari kedepan nilai *return* indeks Euro 50 CFD (*Contract For Difference*) dapat dilihat pada Tabel 1.

Tabel 1. Nilai Ramalan *Return* Indeks Euro 50

| Hari             | Nilai Ramalan |
|------------------|---------------|
| 28 November 2014 | -0,00233      |
| 01 Desember 2014 | -0,00357      |
| 02 Desember 2014 | -0,00060      |
| 03 Desember 2014 | -0,00086      |
| 04 Desember 2014 | -0,00189      |
| 05 Desember 2014 | -0,00295      |
| 08 Desember 2014 | -0,00017      |
| 09 Desember 2014 | -0,00163      |
| 10 Desember 2014 | -0,00275      |
| 11 Desember 2014 | 0,00386       |
| 12 Desember 2014 | -0,00066      |
| 15 Desember 2014 | 0,00296       |

Tabel 2. Capital Gain

| Hari             | Capital Gain | Profit        | Presentase | Keterangan          |
|------------------|--------------|---------------|------------|---------------------|
| 28 November 2014 | -0.001070    | \$ -1,070081  | 0,107008%  | <i>Capital Loss</i> |
| 01 Desember 2014 | -0.005007    | \$ -5,006555  | 0,500656%  | <i>Capital Loss</i> |
| 02 Desember 2014 | -0.001198    | \$ -1,197716  | 0,119772%  | <i>Capital Loss</i> |
| 03 Desember 2014 | -0.001845    | \$ -1,845145  | 0,184514%  | <i>Capital Loss</i> |
| 04 Desember 2014 | 0.002761     | \$ 2,761462   | 0,276146%  | <i>Capital Gain</i> |
| 05 Desember 2014 | -0.010697    | \$ -10,697358 | 1,069736%  | <i>Capital Loss</i> |
| 08 Desember 2014 | 0.006770     | \$ -6,769827  | 0,676983%  | <i>Capital Loss</i> |
| 09 Desember 2014 | -0.004846    | \$ -4,845707  | 0,484571%  | <i>Capital Loss</i> |
| 10 Desember 2014 | -0.022677    | \$ -22,677407 | 2,267641%  | <i>Capital Loss</i> |
| 11 Desember 2014 | -0.030288    | \$ -30,288112 | 3,028811%  | <i>Capital Loss</i> |
| 12 Desember 2014 | -0.030467    | \$ -30,467049 | 3,046705%  | <i>Capital Loss</i> |
| 15 Desember 2014 | -0.055832    | \$ -55,831885 | 5,583188%  | <i>Capital Loss</i> |

## 4.5 Capital Gain

Berdasarkan hasil ramalah *return* ( $\widehat{X}_t$ ) dengan model GRNN terbaik dapat dihitung *capital gain* pada indeks harga saham Euro 50 (*Contract For Diffrence*). Perhitungan *capital gain* dilakukan dengan menggunakan asumsi bahwa dana yang di investasikan adalah sebesar \$1000 diketahui nilai *return* pada tanggal 27 November 2014 sebesar 0,00084. Dari hasil perhitungan *capital gain* dengan persamaan 2.26 dan perhitungan profit dengan Persamaan 2.27 dapat diketahui besarnya keuntungan maupun kerugian yang diperoleh jika investor ingin menjual sahamnya dua belas hari kedepan yaitu

## 5. PENUTUP

### 5.1 Kesimpulan

Berdasarkan analisis dan pembahasan yang telah dilakukan dapat diambil kesimpulan sebagai berikut:

1. Untuk memperoleh arsitektur Jaringan Syaraf Tiruan yang optimal sebagai model peramalan data runtun waktu dapat menggunakan Metode General Regression Neural Network (GRNN) didapat  $R^2$  *training* sebesar 0.9919 atau 99.19% dan  $R^2$  *testing* sebesar 0.9846 atau 98.46% dengan nilai *spread* 1. Diperoleh model GRNN sebagai berikut:

$$\widehat{X}_t = \frac{S_W}{S_S} = \frac{\sum_{i=1}^{375} W_i \times \theta_i}{\sum_{i=1}^{375} \theta_i} = \frac{\sum_{i=1}^{375} W_i \times e^{-(b\sqrt{(X_{t-1}-X_{t-i})^2+(X_{t-2}-X_{t-2i})^2+(X_{t-12}-X_{t-12i})^2})}}{\sum_{i=1}^{375} e^{-(b\sqrt{(X_{t-1}-X_{t-i})^2+(X_{t-2}-X_{t-2i})^2+(X_{t-12}-X_{t-12i})^2})}}$$

Dimana  $W_i$  = bobot lapisan hasil Pelatihan jaringan GRNN

$\theta_i$  = nilai-nilai masing neuron pada layer pola

2. Dengan investasi sebesar \$1000 besarnya *capital gain* di gunakan untuk menduga keuntungan yang mungkin diperoleh jika investor menjual sahamnya dalam dua belas hari kedepan diperoleh kerugian tertinggi atau *capital loss* pada 15 November 2014 sebesar 5,583188% dan profit tertinggi atau *capital gain* pada tanggal 10 Desember 2014 sebesar 2,267641%

### 5.2 Saran

*General Regression Neural Network* dapat memodelkan data *return* dengan baik, namun perlu dilakukan pengujian lebih lanjut dengan membandingkan kecepatan pembelajaran (*spread*). Kecepatan pembelajaran (*spread*) yang dipakai dalam penelitian ini adalah *default* 1. Selain itu pada penelitian selanjutnya disarankan untuk menggunakan model *Modified General Regression Neural Network* dengan kombinasi ARCH, GARCH, IGARCH, APARCH sebagai input.

Hasil dari *capital gain* dapat dipakai sebagai salah satu acuan dalam melakukan investasi saham dengan melihat besarnya kerugian maupun keuntungan yang mungkin akan dialami oleh seorang investor terutama jika ingin melakukan investasi dalam jangka waktu yang pendek.

## 6. DAFTAR PUSTAKA

- Box, G.E.P., G.M.Jenkins, And G.C.Reinsel. 1994. *Time Series Analysis : Forecasting and Control, third edition*. Prentice Hall, New Jersey.
- Kusumadewi, S. 2004. *Membangun Jaringan Syaraf Tiruan Menggunakan Matlab dan Excel Link*. Graha Ilmu. Yogyakarta.

- Leung, M.T.,Chen,A.N., dan H. Daouk. 2000. *Forecasting Exchanges rates using general regression neural networks*, *Computers and Operation Research Vol. 27 2000 1093-1110*
- Makridakis, S; S.C. Wheelwright dan V.E. McGee. 1999. *Metode dan Aplikasi Peramalan*. Edisi Kedua Jilid Satu. Alih Bahasa Hari Suminto. Binarupa Aksara. Jakarta
- Samsul, M. 2006. *Pasar Modal dan Manajemen Portofolio*. Edisi pertama. Erlangga. Jakarta
- Sprecht, D.F., 1991 *A Generalized Regression Neural Network*, *IEEE Transactions on Neural Networks*, vol.2,No.6,page 568-576
- Stoxx. 2014. *Stoxx Index Methodology Guide* . [www.stoxx.com](http://www.stoxx.com) . Tanggal akses 24 September 2014
- Tsay, R.S. 2002. *Analysis of Financial Time Series*. John Wiley and Sons, Inc.New York.
- Warsito, B. 2009. *Kapita Selekta Statistika Neural Network*. BP Undip Semarang
- Wei, W.W.S. 1990. *Time Series Analysis: Univariate and Multivariate Method*. Addison-Wesley Publishing Company. New York.